

Referências bibliográficas

CARNEIRO, D. D.; WU, T. **Taxa de Sacrifício e Desgaste da Política Monetária em 2004.** *Carta Econômica Galanto*. Março, 2004.

CLARIDA, R.; GALI, J.; GERTLER, M. **Monetary Policy Rules and Macroeconomic Stability: Evidence and some theory.** *Quarterly Journal of Economics*, Vol. 115, 145-180, 2000.

----- **The Science of Monetary Policy: a New Keynesian Perspective.** *Journal of Economic Literature*, Vol 37, 1661-1707, 1999.

CUKIERMAN, A.; GERLACH, S. **The Inflation Bias Revisited: Theory and Some International Evidence.** *The Manchester School*, Blackwell Publishing Vol 71 (5), 541-565, 2003.

CUKIERMAN , A. **Non Linearities in Taylor Rules – Causes, Consequences and Evidence.** *Economic Annual Meeting of the Central Bank of Uruguay*. Mimeo, 2004.

DOLADO, J. J.; MARÍA-DOLORES, R.; NAVIEIRA, M. **Are Central Banks' Reaction Functions Asymmetric? Evidence for Some Central Banks.** Discussion Paper no. 2441, CEPR, London, 2000.

----- **Are Monetary-Policy Reaction Functions Asymmetric? the Role of Nonlinear in the Phillips Curve.** *European Economic Review*. No Prelo.

DOLADO, J. J.; MARÍA-DOLORES, R.; RUGE-MURCIA, F. J. **Nonlinear Monetary Policy Rules: Some New Evidence for the U.S.** *Discussion Paper* no. 3405, CEPR, London, 2002.

DORNBUSCH, R. **Expectations and Exchange Rates Dynamics.** *Journal of Political Economy*, Vol 84 (6), 1161-1176, 1976.

EDWARDS, S. **Crises Prevention: Lessons from Mexico and East Asia.** *NBER Working Papers*, w7233, 1999.

----- **Interest Rate Volatility, Capital Controls and Contagion.** *NBER Working Papers*, w6756, 1998.

FRANCO, G. H. B. **O Plano Real e Outros Ensaio** - 2ª Edição. Rio de Janeiro, 1995.

GARCIA, M. G. P.; DIDIER, T. **Very High Interest Rates and the Cousin Risks: Brazil During the Real Plan.** *Pesquisa e Planejamento Econômico*, Vol 33 (2), 253-297, 2003.

-----; OLIVARES LEANDRO, G. A. **O Prêmio de Risco da Taxa de Câmbio no Brasil durante o Plano Real.** *Revista Brasileira de Economia*, Vol 55 (2), 2001.

-----; VALPASSOS, M. V. **Capital Flows, Capital Controls and Currency Crisis: The Case of Brazil in the Nineties.** Em: Larrain, Filipe (org) "*Capital Flows, Capital Controls & Currency Crises. Latin America in the 1990's*". v1, 2000.

GOLDFAJN, I.; CARDOSO, E. **Capital Flows to Brazil – The Endogeneity of Capital Controls.** *IMF Staff Papers*, Vol 45 (1), 1998.

GUIMARÃES, E. A. **O Viés do IGP e Suas Conseqüências.** *Mimeo*, 2003.

HAMILTON, JAMES D. **Time Series Analysis.** New Jersey. Princeton University Press, 1994.

MUNDELL, R. A. **The Monetary Dynamics of International Adjustment under Fixed and Flexible Exchange Rates.** *Quarterly Journal of Economics*, Vol. 84, 227-257, 1960.

MINELLA, A.; FREITAS, P. S.; GOLDFAJN, I.; MUINHOS, M. K. **Inflation Targeting in Brazil: Lessons and Challenges.** *Working Paper Series* no. 53. Banco Central do Brasil, 2002.

PASTORE, A. **Por que a Política Monetária Perde a Eficácia?.** *Revista Brasileira de Economia*, 50, 1996.

PERRON, P. **The Great Crash, the Oil Price Shock and the Unit Root Hypothesis.** *Econometrica*, Vol 57 (6), 1361-1401, 1989.

RUGE-MURCIA, F. J. **The Inflation Bias When the Central Banker Targets the Natural Rate of Unemployment.** *European Economic Review*, Vol 48, 91-107, 2004.

SALGADO, M. J.; GARCIA, M. G. P.; MEDEIROS, M. C. **Monetary Policy During Brazil's Real Plan: Estimating the Central Bank's Reaction Function.** *Revista Brasileira de Economia*, No prelo.

TAYLOR, J. B. **Recent Developments in the Use of Monetary Policy Rules.** Stanford University. *Mimeo*, 2000.

----- **Discretion Versus Policy Rules in Practice.** *Carnegie-Rochester Conference Series on Public Policy* 39, 195-214, 1993.

WILLIAMSON, J. **A Economia Aberta e a Economia Mundial: um Texto de Economia Internacional**. Rio de Janeiro. Editora Campus, 1989.

WOODFORD, M. **Interest and Prices**. New Jersey. Princeton University Press, 2003.

-----; ROTEMBERG, J. **An Optimization-Based Econometric Model for the Evaluation of Monetary Policy**. *NBER Technical Working Papers* no. 233, 1998.

Apêndice 1 – O modelo de *Markov-Switching*

Neste Apêndice iremos descrever o processo de estimação de *Markov-Switching* utilizado na avaliação empírica desenvolvida no capítulo 4. A idéia central é estimar parâmetros que possam mudar de acordo com sub-amostras do conjunto de dados. Hamilton (1994) apresenta detalhes de derivação da estimação. De forma genérica, a equação (a1) descreve o processo que queremos estimar.

$$\mathbf{y}_t = \mathbf{b}_{s_t} \mathbf{x}_t + \boldsymbol{\varepsilon}_t \quad \text{eq(a1)}$$

onde $\boldsymbol{\varepsilon}_t \sim \text{iid } N(0, \sigma^2)$. O objetivo será estimar o estado da natureza s_t como sendo uma variável latente que segue uma cadeia de Markov de N estados distintos, assumindo que s_t e $\boldsymbol{\varepsilon}_t$ são independentes para todo t e τ . Por fim, em um processo com N estados da natureza distintos temos que $s_t \in [1, 2, \dots, N]$ e dizemos que quando $s_t = j$ temos o processo no j -ésimo estado da natureza.

A equação (a1) é a representação vetorial mais genérica possível para um processo gerador de dados cujos parâmetros seguem uma cadeia de Markov. Seja $\mathbf{y}_t$ um vetor ($n \times 1$), contendo as observações da variável explicada. A matriz $\mathbf{x}_t$ é composta por todas as variáveis explicativas incluindo defasagens da própria variável, variáveis exógenas contemporâneas e defasadas e o intercepto.

Seja $\mathbf{Y}_t = (\mathbf{y}_t', \mathbf{y}_{t-1}', \dots, \mathbf{y}_{t-m}', \mathbf{x}_t', \mathbf{x}_{t-1}', \dots, \mathbf{x}_{t-m})'$ um vetor que contém todas as observações até a data t . Se o processo for governado pelo estado da natureza $s_t = j$, na data t , então a densidade condicional de $\mathbf{y}_t$ é dada pela equação (a2):

$$f(\mathbf{y}_t | s_t = j, \mathbf{x}_t, \mathbf{Y}_{t-1}; \boldsymbol{\alpha}) \quad \text{eq(a2)}$$

onde $\boldsymbol{\alpha}$ é um vetor de parâmetros que caracterizam a densidade condicional. Havendo N diferentes regimes haverá N diferentes densidades, representadas para cada $j = 1, 2, \dots, N$. Ou seja, a equação (a2) nos diz que a função de densidade depende apenas do estado da natureza corrente e não dos estados passados. E ainda, assumimos que os estados da natureza seguem uma Cadeia de Markov, isto é, o estado da natureza corrente depende apenas do estado da natureza

imediatamente anterior, independente das demais variáveis ou da trajetória pregressa de estados da natureza, o que implica em dizer que $\Pr\{s_t = j \mid s_{t-1} = i, s_{t-2} = k, \dots, \mathbf{Y}_{t-1}\} = \Pr\{s_t = j \mid s_{t-1} = i\} = p_{ij}$.

Assim, construímos um vetor ($N \times 1$), chamado $\boldsymbol{\eta}_t$, que agrega cada uma das funções de densidade condicional dados os estados da natureza, como mostra a equação (a3). A forma funcional dessas densidades depende da hipótese de normalidade dos erros.

$$\boldsymbol{\eta}_t = \begin{bmatrix} f(\mathbf{y}_t \mid s_t = 1, \mathbf{x}_t, \mathbf{Y}_{t-1}; \boldsymbol{\alpha}) \\ \vdots \\ f(\mathbf{y}_t \mid s_t = N, \mathbf{x}_t, \mathbf{Y}_{t-1}; \boldsymbol{\alpha}) \end{bmatrix} = \begin{bmatrix} \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(\mathbf{y}_t - \mathbf{b}_1 \mathbf{x}_t)^2}{2\sigma^2}\right\} \\ \vdots \\ \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(\mathbf{y}_t - \mathbf{b}_N \mathbf{x}_t)^2}{2\sigma^2}\right\} \end{bmatrix} \quad \text{eq(a3)}$$

Além dos parâmetros presentes no vetor $\boldsymbol{\alpha}$, que caracterizam as funções de distribuição vistas na equação (a3), ainda há outros parâmetros populacionais que na dinâmica da séries, que são as várias probabilidades de transição p_{ij} . Mesmo assim, se unirmos todos os parâmetros em uma vetor $\boldsymbol{\theta}$ e assumir conhecido este vetor, ainda assim, não seria conhecido o estado da natureza vigente a cada instante do tempo.

Desta forma, é preciso definir qual a inferência ótima dos estados da natureza. Seja $\Pr\{s_t = j \mid \mathbf{Y}_{t-1}; \boldsymbol{\theta}\}$ esta inferência sobre o valor de s_t baseada nos dados coletados até a data t , supondo o vetor $\boldsymbol{\theta}$ conhecido. E, para cada $j = 1, 2, \dots, N$, armazenamos a probabilidade associada como um elemento do vetor ($N \times 1$) denotado por $\xi_{t|t}$. Por fim, seja $\xi_{t+1|t}$ o vetor com as probabilidades, para cada estado da natureza, de o estado futuro ser o j -ésimo estado da natureza descrito, portanto, por $\Pr\{s_{t+1} = j \mid \mathbf{Y}_t; \boldsymbol{\theta}\}$. As equações (a4) e (a5) descrevem o processo iterativo capaz de gerar inferências e previsões ótimas, para cada data t da amostra.

$$\xi_{t|t} = \frac{(\xi_{t|t-1} * \boldsymbol{\eta}_t)}{\mathbf{1}'(\xi_{t|t-1} * \boldsymbol{\eta}_t)} \quad \text{eq(a4)}$$

$$\xi_{t+1|t} = \mathbf{P}\xi_{t|t} \quad \text{eq(a5)}$$

Na equação (a4) $\mathbf{1}$ denota um vetor ($N \times 1$) em que todos os elementos são iguais a 1, a notação $\cdot *$ indica multiplicação dos vetores elemento a elemento, e a matriz $\mathbf{P}$ é a matriz de transição onde o elemento da i -ésima coluna e j -ésima linha corresponde a probabilidade de transição p_{ij} . Perceba que, com esta notação, o somatório de cada coluna da matriz $\mathbf{P}$ é obrigatoriamente igual a 1.

Deste modo podemos escrever a função de log-verossimilhança $L(\boldsymbol{\theta})$ para as observações $\mathbf{Y}_t$ calculada com base nos valores de $\boldsymbol{\theta}$ utilizados nas iterações das equações (a4) e (a5) como mostra a equação (a6).

$$L(\boldsymbol{\theta}) = \sum_{t=1}^T \log(f(\mathbf{y}_t | \mathbf{x}_t, \mathbf{Y}_{t-1}; \boldsymbol{\theta})) = \sum_{t=1}^T \log(\mathbf{1}'(\boldsymbol{\xi}_{t|t-1} \cdot * \boldsymbol{\eta}_t)) \quad \text{eq(a6)}$$

Definimos, então, uma função de máxima verossimilhança em função dos parâmetros do vetor $\boldsymbol{\theta}$. Podemos, então, encontrar numericamente os parâmetros que maximizam a função $L(\boldsymbol{\theta})$ e, assumindo uma condição inicial para $\boldsymbol{\xi}_{1|0}$, que atenda apenas à exigência de ser descorrelatada dos demais parâmetros, é possível mostrar que a melhor estimativa para as probabilidades de transição p_{ij} é dada pela equação (a7).

$$p_{ij} = \frac{\sum_{t=2}^T \Pr\{s_t = j, s_{t-1} = i | \mathbf{Y}_t; \boldsymbol{\theta}\}}{\sum_{t=2}^T \Pr\{s_{t-1} = i | \mathbf{Y}_t; \boldsymbol{\theta}\}} \quad \text{eq(a7)}$$

Ou seja, a probabilidade p_{ij} estimada consiste basicamente do número de vezes que o regime j aparenta ter sido antecedido pelo regime i . Calculadas as probabilidades de transição, para concluir a estimação dos parâmetros que compõem o vetor $\boldsymbol{\theta}$, falta obter um estimador para a matriz $\mathbf{b}$.

Hamilton (1994) mostra que o estimador da matriz $\mathbf{b}$ satisfaz à condição de ortogonalidade de uma estimação de mínimos quadrados ordinários ponderada pela matriz de probabilidade. Sendo $\boldsymbol{\beta}$ esta estimação da matriz de parâmetros $\mathbf{b}$, as equações (a8), (a9) e (a10) apresentam como obter esta matriz.

$$\boldsymbol{\beta} = \left[\sum_{t=1}^T \left[\tilde{\mathbf{x}}_t(\mathbf{j}) \right] \left[\tilde{\mathbf{x}}_t(\mathbf{j}) \right]' \right]^{-1} \left[\sum_{t=1}^T \left[\tilde{\mathbf{x}}_t(\mathbf{j}) \right] \left[\tilde{\mathbf{y}}_t(\mathbf{j}) \right]' \right] \quad \text{eq(8)}$$

$$\tilde{\mathbf{y}}_t(\mathbf{j}) = \mathbf{y}_t \sqrt{\Pr\{\mathbf{s}_t = j \mid \mathbf{Y}_t; \boldsymbol{\theta}\}} \quad \text{eq(9)}$$

$$\tilde{\mathbf{x}}_t(\mathbf{j}) = \mathbf{x}_t \sqrt{\Pr\{\mathbf{s}_t = j \mid \mathbf{Y}_t; \boldsymbol{\theta}\}} \quad \text{eq(10)}$$

Por fim a variância dos resíduos, σ^2 , é calculada de acordo com a equação (a11).

$$\sigma^2 = T^{-1} \sum_{t=1}^T \sum_{j=1}^J (\mathbf{y}_t - \mathbf{z}_t' \boldsymbol{\beta}_j)^2 \Pr\{\mathbf{s}_t = j \mid \mathbf{Y}_t; \boldsymbol{\theta}\} \quad \text{eq(a11)}$$

Desta forma, estimada a matriz $\boldsymbol{\beta}$, podemos voltar nas equações (a4) e (a5) e reestimar a probabilidade de ocorrência de cada estado da natureza, dados os novos parâmetros. Teremos então que maximizar, novamente, as função de log-verossimilhança, a fim de obter novas probabilidades de transição e novos parâmetros para a matriz $\boldsymbol{\beta}$. Este processo deve ser repetido até que se encontre a convergência da função de log-verossimilhança, indicando assim o conjunto de parâmetros que nos leva a um máximo local da função.

Finalmente, a matriz $\boldsymbol{\beta}$ é composta por N vetores que correspondem aos parâmetros em cada um dos estados da natureza. E, como vimos na equação (8), estes parâmetros são calculados a partir de N regressões lineares, de modo que podemos construir as estatísticas de teste para os coeficientes da matriz $\boldsymbol{\beta}$ de modo usual.

Apêndice 2 – Teste de Estacionariedade da Taxa Selic

No exercício empírico realizado no capítulo 4 temos um possível problema de presença de raiz unitária na série explicada, isto é, na taxa Selic. Ao longo do trabalho desenvolvemos alguns argumentos qualitativos que nos fazem rejeitar a hipótese de não-estacionariedade.

Além disso, em função do reduzido tamanho da amostra, os resultados dos testes em prol da presença de raiz unitária são questionáveis, já que a probabilidade de aceitar a hipótese nula quando ela é falsa é muito grande, isto é, a potência do teste é muito baixa.

Mesmo assim, utilizamos o teste de Phillips-Perron e rejeitamos fortemente a hipótese de não estacionariedade. Para isso, primeiro fazemos uma regressão do nível da taxa Selic em um intercepto, uma tendência determinística e *dummies* para os períodos de crise. Em seguida utilizamos os resíduos desta regressão no teste de Phillips-Perron.

O objetivo é expurgar o comportamento assintótico que a taxa Selic aparenta ter. Assim utilizamos duas séries diferentes para a tendência, a primeira foi simplesmente $\{1/t\}$ e a segunda $\{\ln(t)/t\}$, onde t é o tempo. O gráfico (b1) mostra a série da taxa Selic, bem como as séries de tendência que utilizaremos, e os períodos sombreados correspondem às intervenções.




Gráfico (b1): Taxa Selic, Tendências Determinísticas e *Dummies*

Portanto, realizamos duas regressões, uma utilizando a primeira tendência, ou seja, $\ln(t)/t$ e a segunda alterando a série utilizada como tendência determinística, passando a usar a série $1/t$. Feitas estas regressões aplicamos o teste de Phillips-Perron nos resíduos obtidos. Os valores críticos do teste, em cada um dos dois casos, correspondem, respectivamente a -5,10 e -5,04. Por fim, as estatísticas tabeladas para o teste dados os níveis de significância de 1%, 5% e 10% valem -2,62, -1,95 e -1,61. E, deste modo, o teste rejeita fortemente a hipótese nula de presença de raiz unitária.